

# ARIMA-LSTM组合模型在基于SPI干旱预测中的应用 ——以青海省为例

张建海<sup>1</sup>, 张 棋<sup>2</sup>, 许德合<sup>2</sup>, 丁 严<sup>2</sup>

(1 青海水文水资源勘测局, 青海 西宁 810000; 2 华北水利水电大学, 河南 郑州 450000)

**摘 要:** 开展干旱预测是有效应对干旱风险的前提基础。利用 1958—2017 年青海省 38 个气象站点逐日降水量数据计算多尺度标准化降水指数(SPI), 并建立了 SPI 序列自回归移动平均模型(ARIMA)、长短时记忆神经网络模型(LSTM)和基于二者优点提出的 ARIMA-LSTM 组合模型; 对模型参数进行率定和验证后, 利用所建立的模型, 以西宁站点为例, 对多尺度 SPI 值进行预测, 借助均方根误差(RMSE)、平均绝对百分比误差(MAPE)和决定系数  $R^2$  对所有预测模型的有效性进行判定。结果表明: ARIMA-LSTM 组合模型在 SPI1 和 SPI12 的 RMSE 值分别为 0.159 7 和 0.181 0, 均低于 ARIMA 模型的 1.265 4 和 0.293 3, 说明 ARIMA 模型与 ARIMA-LSTM 组合模型对 SPI 的预测精度都与时间尺度有关, ARIMA 模型的预测精度随着时间尺度的增加而逐渐提高; 结合 GIS 并利用实测数据与模型的预测数据相比较说明 ARIMA-LSTM 组合模型相比于单一 ARIMA 模型的预测精度更高, 且能够很好拟合不同时间尺度的 SPI 值。

**关 键 词:** 干旱预测; SPI; ARIMA-LSTM 组合模型; 青海省

**文章编号:** 1000-6060(2020)04-1004-10(1004~1013)

干旱是最常见、最复杂的自然灾害之一, 也是对人类社会影响最为严重的气象灾害之一<sup>[1]</sup>。相较于其他自然灾害, 干旱发展缓慢, 特征不易量化, 影响方式直接, 危害面积较大<sup>[2]</sup>。干旱是指水分收支或供求不平衡形成的水分短缺现象<sup>[3]</sup>。干旱作为一种气象灾害, 长期困扰着工农业生产<sup>[4]</sup>。干旱程度常利用干旱指数进行定量评价<sup>[5]</sup>。干旱指数是干旱灾害量化和评估研究的基础之一<sup>[6]</sup>, 国内外常用的分析指数有: Palmer 干旱指数(PDSI)<sup>[7-8]</sup>、标准化降水指数(SPI)<sup>[9-12]</sup>、综合气象干旱指数(CI)等<sup>[13]</sup>。其中, SPI 适用范围广, 易于计算, 因此, 成为在实际运用当中最广泛并且适用于所有气候的干旱指标<sup>[14]</sup>。于家瑞等<sup>[15]</sup>利用不同时间尺度的 SPI 值并结合游程理论来分析黑龙省干旱的时空演变特征, 对历史的连早期以及干旱频率强度的趋势进行了探究, 发现 SPI 能够较好监测历史旱情。

目前, ARIMA、人工神经网络(ANN)、支持向量机(SVM)是常见的干旱预测模型<sup>[14]</sup>。其中 ARIMA 模型是常用的数据驱动模型, 多用来拟合并预测时间序列数据, 韩萍等<sup>[16]</sup>利用 ARIMA 模型预测了多个时间尺度的 SPI, 并对多尺度 SPI 的预测精度进行了对比; ANN 模型被杨慧荣等<sup>[13]</sup>用来和 ARIMA 模型进行对比, 通过 ARIMA 和 ANN 模型对 SPEI 进行预测, 并将实际值与预测值进行对比, 发现两种预测模型对不同时间尺度的 SPEI 预测精度不同。目前的文章大多以 ARIMA 为主的线性模型和 ANN 为主的非线性模型来预测干旱指数的时间序列, 其中线性模型和非线性模型各有利弊, 由于线性模型不能识别非线性特征, 而非线性模型不能识别线性特征, 因此本文利用线性模型和非线性模型组合来预测干旱情况, 即 ARIMA-LSTM 组合模型。相比于前人的研究, 本文选取的 LSTM 模型在预测长期数据

收稿日期: 2019-11-05; 修订日期: 2020-06-08

基金项目: 国家自然科学基金(51679089, 51609082, 51709107)资助

作者简介: 张建海(1968-), 男, 高级工程师, 学士, 研究方向为水利工程与水文水资源. E-mail: 1291065549@qq.com

通讯作者: 张棋. E-mail: 895300576@qq.com

的情况下优于传统的 ANN 模型。LSTM 模型是循环神经网络模型(RNN)的拓展,其中 RNN 相比于 ANN 在神经元的隐藏层数上要多,并且 RNN 能够通过先前的事件推断后续事件,即 RNN 最大的优点是具有记忆功能;但随着事件的时间间隔不断增大时, RNN 会丧失它的学习能力,又因为 RNN 在模型训练时存在梯度消失和梯度爆炸问题导致很难应用在解决实际问题上<sup>[17]</sup>。而 LSTM 则是 RNN 的变体,通过加入三种特殊的门层(遗忘门,输入门,输出门)来确定细胞状态中丢弃什么样的信息、更新什么样的信息和输出什么样的信息,因此在长期记忆中优于 RNN;同时, LSTM 通过添加正则项和激活函数来避免梯度消失和爆炸,近年来 LSTM 也成功地应用于自然语言处理和时间序列预测领域。ZHANG 等<sup>[18]</sup>为了预测长期地下水位深度而开发了 LSTM 模型,利用决定系数( $R^2$ )等模型评价指标对预测结果进行评价并取得了较好的效果,证明了该模型能够较好地保存和学习以往的信息,并发现该模型可以作为长期预测地下水位深度的另一种方法。

本研究通过青海省 1958—2017 年的 38 个气象站点降水量数据来计算多尺度 SPI 值,由于气象站点过多,因此仅以西宁站为例进行 ARIMA 和 LSTM 建模过程展示。并以三种模型评价指标对两种模型预测精度进行评价,结合 ArcGIS 的样条函数插值法对青海省 2017 年的 SPI 实际值与模型预测值进行可视化展示与分析。

## 1 研究区概况

近年来全国旱涝灾害频发,西北干旱地区更是首当其冲<sup>[19]</sup>。青海省地势总体呈西高东低,西部海拔高峻,向东倾斜,呈梯形下降,东部地区为青藏高原向黄土高原过渡地带,地形复杂,地貌多样<sup>[20]</sup>。全省属于高原大陆性气候,是全球同纬度最干旱的地区之一<sup>[21]</sup>,同时这里受西风带气候、高原季风和东亚季风气候影响,降水变率大,干旱频率高,是我国气候变化的敏感区和生态脆弱区<sup>[22]</sup>。本文以青海省为例,利用机器学习模型对研究区干旱情况进行分析预测。

## 2 数据及方法

### 2.1 数据来源

图形数据包括:1.青海省行政区划图;2.青海省水系图;3.青海省土地利用图。表格数据包括:1.各市降水量数据(青海省统计年鉴);2.青海省气象站点数据;3.气象站点逐日降水量数据。本文选用 1958—2017 年青海省境内 38 个监测连续的气象站数据来自中国气象数据网(<http://data.cma.cn/>)。

### 2.2 研究方法

**2.2.1 标准化降水指数(SPI)** SPI 是由美国科学家 MCKEE 等<sup>[12]</sup>与 1993 年开发的一种多时间尺度的

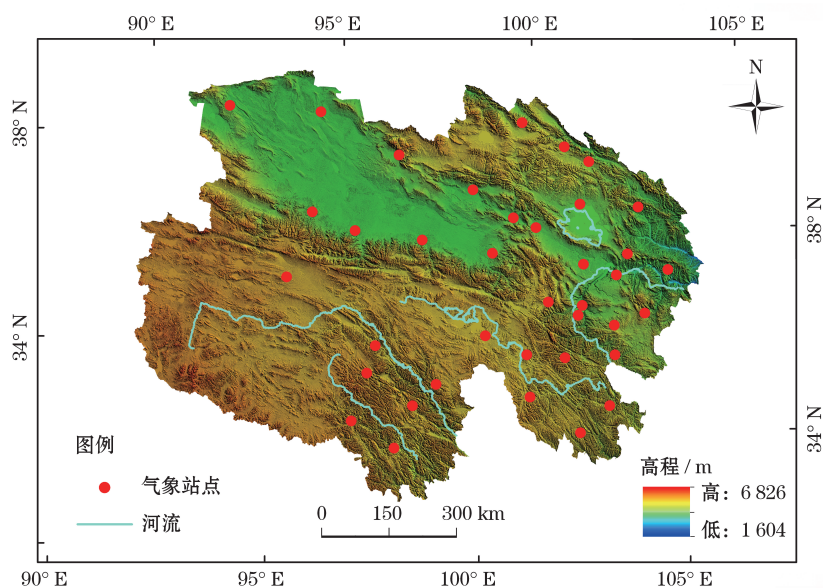


图 1 青海省气象站点分布与研究区划图

Fig. 1 Meteorological station distribution and study area map of Qinghai Province



干旱指数,采用Gamma函数来描述降水量变化,只需降水量即可计算,通过干旱指数值可判别是否发生干旱<sup>[23]</sup>。

SPI指数公式为<sup>[5]</sup>:

$$SPI=G \frac{t-(u_2t+u_1)t+u_0}{[(l_3t+l_2)t+l_1]t+1} \tag{1}$$

$$t=\sqrt{\ln\frac{1}{Y(x)^2}} \tag{2}$$

式中:  $Y(x)^2$  为与 $\Gamma$ 函数相关的降水量分布概率; $x$ 为样本值(即降水量); $G$ 为正负系数; $u_0$ 、 $u_1$ 、 $u_2$ 和 $l_1$ 、 $l_2$ 、 $l_3$ 为常数:

$$u_0=2.515\ 517\quad u_1=0.802\ 853\quad u_2=0.010\ 328$$

$$l_1=1.432\ 788\quad l_2=0.189\ 269\quad l_3=0.001\ 308$$

当 $Y(x)>0.5$ 时, $G=1$ ,当 $Y(x)\leq 0.5$ 时, $G=-1$ 。

$Y(x)$ 由 $\Gamma$ 函数概率密度积分公式求得,公式为:

$$Y(x)=\frac{2}{\beta\gamma\Gamma(\gamma_0)}\int_0^x x^{y-1}e^{-\frac{x}{\beta}}dx,x>0 \tag{3}$$

式中: $\gamma$ 、 $\beta$ 为 $\Gamma$ 分布函数的形状和尺度参数。

本文计算了1958—2017年的4个月尺度的SPI值(分别为1个月、3个月、6个月和12个月),并利用干旱分级表(表1)来表征干旱情况<sup>[24-25]</sup>。

表1 标准化降水指数干旱分级

Tab. 1 Drought classification based on SPI

等级	类型	SPI 范围
1	无旱	$-0.5 < SPI$
2	轻旱	$-1.0 < SPI \leq -0.5$
3	中旱	$-1.5 < SPI \leq -1.0$
4	重旱	$-2.0 < SPI \leq -1.5$
5	特旱	$SPI \leq -2.0$

2.2.2 ARIMA模型 ARMA模型由下式表示<sup>[26]</sup>:

$$Y_t=\varphi_1Y_{t-1}+\varphi_2Y_{t-2}+\cdots\varphi_pY_{t-p}+e_t-\theta_1e_{t-1}-\theta_2e_{t-2}-\cdots\theta_qe_{t-q} \tag{4}$$

记作ARIMA( $p,d,q$ )。若引进延迟算子 $B$ ,则ARIMA( $p,d,q$ )方程可简记为:

$$\varphi_p(B)\Delta^dY_t=\theta_q(B)e_t \tag{5}$$

其中:

$$\varphi_p(B)=1-B\varphi_1-B^2\varphi_2-\cdots B^p\varphi_p \tag{6}$$

$$\theta_q(B)=1-B\theta_1-B^2\theta_2-\cdots B^q\theta_q \tag{7}$$

式中: $Y_t$ 为时间序列值; $\varphi_i(i=1,2,\cdots,p)$ 和 $\theta_j(j=1,2,\cdots,q)$ 分别为自回归系数和滑动平均系数; $e_t$ 为白

噪声序列,且 $e_t\sim N(0,\sigma^2)$ 。选取1958—1995年数据作为训练集,1996—2017年数据作为测试集。

2.2.3 LSTM模型 LSTM是RNN的一种拓展,结构见图2。LSTM与RNN最大的不同在于隐藏模块中添加了三个门层,分别是忘记门(Forget gate)、输入门(Input gate)和输出门(Output gate)<sup>[17]</sup>。忘记门决定什么样的信息保留,什么样的信息遗忘;输入门用来更新细胞状态,决定什么信息我们需要更新;输出门是一个过滤器,基于当时的细胞状态来选择哪个部分用来输出。其中LSTM隐藏层结构如图3所示。




图2 LSTM模型结构图

Fig. 2 Structure diagram of LSTM model

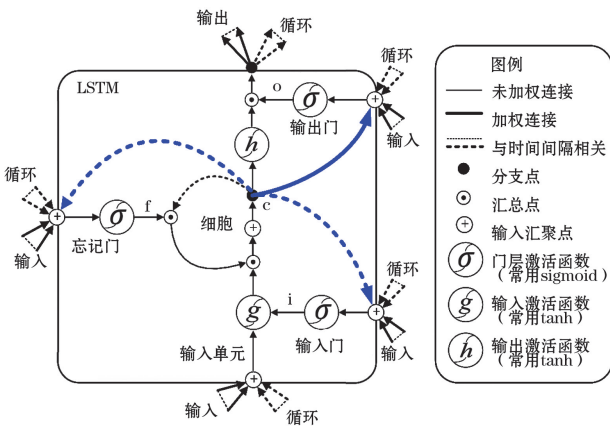


图3 LSTM隐藏层细胞结构

Fig. 3 LSTM cell structure in hidden layer

本文利用LSTM对多时间尺度SPI序列的ARIMA预测残差进行拟合,由于LSTM的隐含层数量决定了模型拟合能力,为了防止过拟合,本文提出了“早停法”,即当损失函数不再下降时停止训练。损失函数定义如下:

$$LOSS=\sum_{i=1}^N(y_i-\hat{y}_i)^2 \tag{8}$$

式中: $y_i$ 是在时间 $i$ 处的观测值; $\hat{y}_i$ 是在时间 $i$ 处的预测值。

本文基于Python3.7平台来搭建LSTM网络,采

用基于时间的反向传播算法进行训练。`batch_size` 设置为 1,其中 1 代表在每个样本之后更新权重,该过程称为随机梯度下降(SGD)。激活函数通常有 sigmoid、tanh 和 relu,由于 sigmoid 在反向传播时很容易出现梯度消失情况,而 tanh 的 SGD 收敛速度太慢,因此本文选用 relu 做激活函数。由于本文选用“早停法”来防止训练过拟合,该方法选取均方误差(MSE)作为损失函数,损失函数越小,说明预测模型精度越高,随着迭代次数不断增加时 MSE 值逐渐下降,直到某一时刻 MSE 值上升时说明模型过拟合,因此早停法在模型 MSE 值上升前一刻停止训练以保证预测模型的精度达到最高。迭代次数本文设置为 300 次,以保证 MSE 能降到最低。对于 LSTM 网络而言,神经元隐藏层数量决定着网络训练速度与预测精度,隐藏层数量太少,导致网络无法训练或效果很差,隐藏层数量过大又导致网络训练速度慢或者出现过拟合现象。本文采用黄金分割法来选择隐藏层神经元数量。黄金分割法是指在区间  $[a,b]$  中找到理想的隐含层节点个数,然后根据黄金分割原理扩展搜索区间,即得到区间  $[b,c]$   $[b=0.619\times(c-a)+a]$ 。

**2.2.4 ARIMA-LSTM 组合模型** 由于 ARIMA 模型是常见的线性预测模型,而 LSTM 模型则相反。本文利用 ARIMA 模型来预测线性特征( $Y_t$ ),利用 LSTM 模型来预测非线性特征( $L_t$ ),最后将线性特征与非线性特征相结合得到组合模型。即:

$$Y_t = L_t + N_t \tag{9}$$

**2.2.5 评价验证指标** 本文选取均方根误差(RMSE)、平均绝对百分比误差(MAPE)和  $R^2$  作为模型评价指标<sup>[27]</sup>,其中  $R^2$  的取值范围通常在  $[0,1]$ ,结果越接近 1 说明拟合效果越好。

(1) RMSE 均方根误差

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (x_i - y_i)^2} \tag{10}$$

(2) MAPE 平均绝对百分误差

$$MAPE = \sum_{i=1}^N \left| \frac{x_i - y_i}{x_i} \right| \times \frac{100}{N} \tag{11}$$

(3) 决定系数  $R^2$

$$R^2 = \frac{\sum_{i=1}^N (y_i - \bar{y})^2 - \sum_{i=1}^N (y_i - \hat{y}_i)^2}{\sum_{i=1}^N (y_i - \bar{y})^2} \tag{12}$$

式中:  $x_i$  是观测值;  $y_i$  是预测值;  $\bar{y}$  是  $y_i$  的均值( $i=$

$1, \dots, N$ );  $N$  是样本数。RMSE 和 MAPE 越接近 0,表示预测值与观测值越接近,  $R^2$  值越接近 1 说明拟合效果越好。

3 结果与分析

3.1 ARIMA 建模流程

**3.1.1 平稳化处理及 ARIMA 模型定阶** 本文以西宁站为例对 ARIMA 进行建模。首先采用单位根检验(ADF)来判断模型的平稳性,若计算所得  $P < 0.05$  (显著水平  $\alpha = 0.05$ ) 则为平稳时间序列,计算结果见表 2。由于表 2 中, SPI1、SPI3、SPI6、SPI12 的 ADF 检验  $P < 0.05$ , 因此可进行下一步,若某一时间尺度  $P > 0.05$ , 则为非平稳时间序列(非平稳时间序列一定不是白噪声序列),需利用差分法对非平稳时间序列进行平稳化处理并进行单位根检验,经检验后满足  $P < 0.05$  则可用自相关函数(ACF)及偏自相关函数(PACF)来为 ARIMA 模型定阶(图 4)。由图 4 可得, SPI3 的 ACF 与 PACF 图均在第二阶之后落在置信区间,而其余 3 个时间尺度在第一阶之后落在置信区间上,因此 SPI3 的  $p$  与  $q$  可取值有 0, 1, 2; 而 SPI1、SPI6、SPI12 的  $p$  与  $q$  可取值有 0 和 1。

表 2 单位根检验  
Tab.2 Unit root test

时间 尺度	单位根 检验	临界值			P 值
		1%	5%	10%	
SPI 1	-20.339 5	-3.443 7	-2.897 4	-2.569 9	0.0
SPI 3	-6.356 7	-3.472 9	-2.880 2	-2.576 7	$9.568\ 5 \times 10^{-9}$
SPI 6	-6.991 4	-3.517 1	-2.899 3	-2.586 9	$7.727\ 8 \times 10^{-10}$
SPI 12	-6.319 8	-3.610 3	-2.939 1	-2.608 0	$3.086\ 1 \times 10^{-8}$

**3.1.2 ARIMA 模型参数估计及适用性检验** 将上一步通过 ACF 和 PACF 图所得 ARIMA( $p, d, q$ ) 的可取值采用 AIC、BIC 和 HQIC 准则来选取最优模型,其结果见表 3。由表 3 可得, SPI1(1, 0, 0)、SPI3(1, 0, 1)、SPI6(0, 0, 1) 和 SPI12(1, 0, 0) 的 AIC、BIC 和 HQIC 值最小,因此判定为最优模型。而 QQ 图和正态分布图能够检验模型的适用性,从图 5 和图 6 可以看出散点在拟合线附近,且残差也满足正态分布,再结合 Ljung-Box 检验,得到 P 值为 0.573 64,说明残差符合白噪声,模型适用于 SPI 的变化趋势。

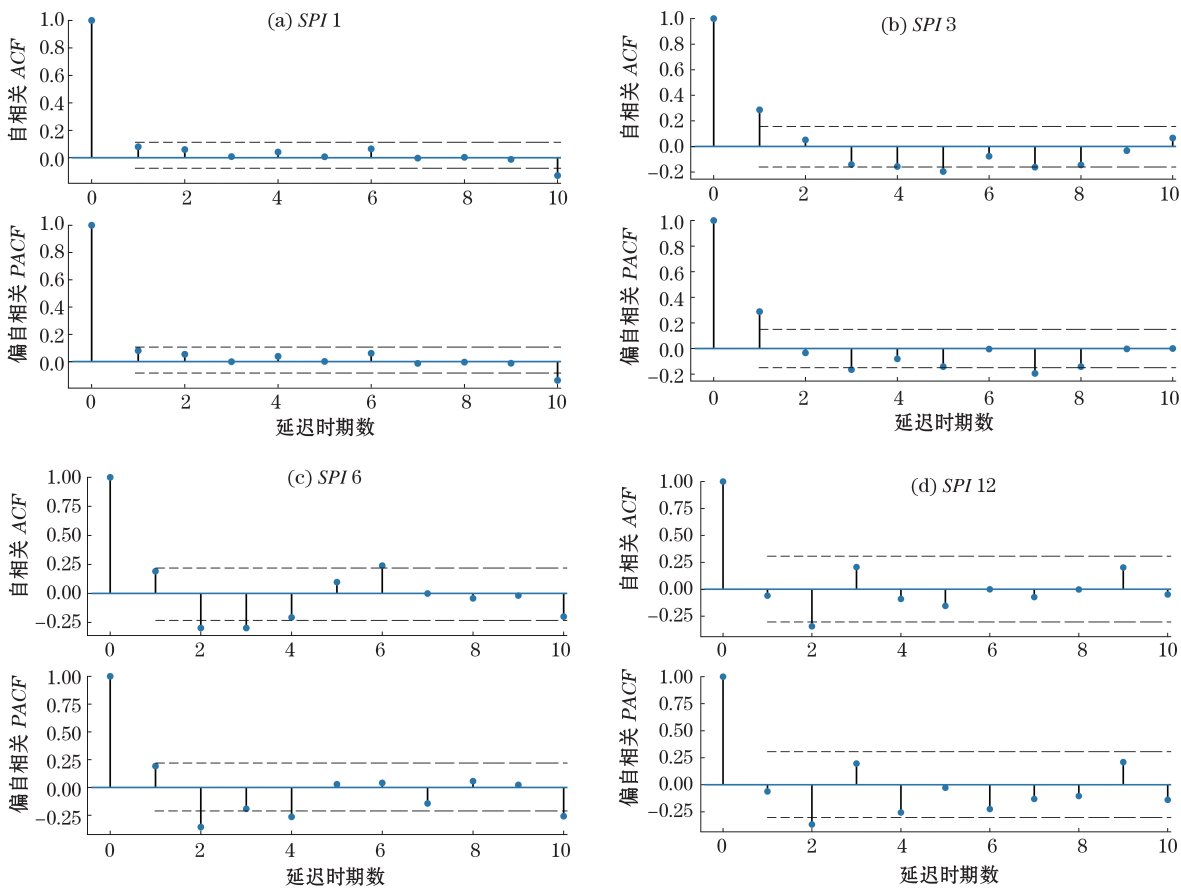


图 4 4 个时间尺度的 ACF 与 PACF 图  
Fig. 4 ACF and PACF diagram of four time scales

表 3 模型参数检验结果  
Tab. 3 Test results of the model parameters

时间尺度	项目	$(p,d,q)$								
		(0,0,0)	(0,0,1)	(0,0,2)	(1,0,0)	(1,0,1)	(1,0,2)	(2,0,0)	(2,0,1)	(2,0,2)
SPI 1	AIC	2 090.2	2 088.6	2 105.1	2 084.7	2 086.2	2 107.8	2 110.4	2 108.4	2 107.1
	BIC	2 099.4	2 102.5	2 202.6	2 079.4	2 099.4	2 203.1	2 210.0	2 204.9	2 202.9
	HQIC	2 093.7	2 093.9	2 291.2	2 081.6	2 093.7	2 291.3	2 298.8	2 294.1	2 292.4
SPI 3	AIC	629.6	609.6	605.7	607.8	601.4	605.2	607.5	607.4	607.8
	BIC	636.6	620.2	619.9	621.9	618.7	622.9	623.1	625.1	629.1
	HQIC	632.4	613.8	611.4	613.5	610.8	612.3	612.9	614.5	616.3
SPI 6	AIC	305.3	291.9	310.8	292.7	293.2	309.1	304.7	294.6	297.8
	BIC	311.1	301.4	321.4	304.1	304.5	317.4	310.0	308.9	310.4
	HQIC	307.6	296.3	313.7	297.3	297.8	322.4	308.7	300.4	299.1
SPI 12	AIC	138.4	134.8	138.5	126.3	133.9	140.5	142.3	141.8	140.4
	BIC	142.7	141.2	141.7	137.0	142.5	154.7	151.7	149.4	145.0
	HQIC	140.1	137.3	142.3	130.5	137.3	149.5	149.5	145.6	148.3

应用各尺度最优模型进行预测,预测结果见图 7,图中蓝色为 SPI 实际值,红色为 SPI 预测值。

3.2 LSTM 建模流程

以西宁站为例,利用 LSTM 模型对 SPI1、SPI3、SPI6 和 SPI12 的 ARIMA 模型预测残差值进行拟合建模分为以下几步:

(1) 输入数据的预处理

通常,神经网络模型处理的数据是归一化数据,范围在  $[-1,1]$ 。通过归一化,学习率不必再根据数据范围进行调整,提高了模型的训练速度。

(2) 网络训练

本文基于 Python3.7 平台来搭建 LSTM 网络,以西宁站 4 个时间尺度的 ARIMA 预测 SPI 值的残差为例,利用箱线图在 4 个时间尺度上直观地显示 LSTM






图5 残差QQ图

Fig. 5 Residual chart of QQ model




图6 残差正态分布图

Fig. 6 Normal distribution map of residual




图7 ARIMA的多时间尺度SPI值的预测(1996—2017)

Fig. 7 Forecast of multi-time scale SPI value of ARIMA model (1996—2017)

隐藏神经元数量与损失函数的关系(图8),采用黄金分割法来选择隐藏层神经元数量。如图8所示,当隐藏层数量在25和35时, $MSE$ 值最低,但隐藏层数量越高,模型训练时间越长,因此神经元隐藏层数选取25。

### (3) 网络输出

由于数据在预处理时采用归一化处理,因此对ARIMA模型残差预测完毕后,得到的并不是最终结果,还需将该时间序列数据进行反归一化处理,即得到模型实际输出数据。

### 3.3 ARIMA-LSTM组合模型的预测

本文选取1958—1996年4个时间尺度SPI值作为训练集,1996—2017年作为测试集。由于ARIMA模型和LSTM模型分别在线性和非线性模型中各有优势,因此提出ARIMA-LSTM组合模型,结果见图

9。图中蓝色为SPI观测值,红色为ARIMA预测值,黑色为ARIMA-LSTM组合预测值。

由于SPI在不同时间尺度适用于不同种类的干旱,3个月以下用于基本干旱监测,6个月以下(包含3个月)SPI值可用于监测农业影响,且通常大部分作物生长期在3~6个月,又由于青海省干旱在四季均有,因此结合ArcGIS强大的空间分析功能,采用样条函数插值法对2017年的各模型SPI<sub>3</sub>及其预测值进行空间分布展示(图10)。

$RMSE$ 、 $MAPE$ 和 $R^2$ 对模型的评价结果见表4,从表中数据可以发现ARIMA模型在SPI<sub>1</sub>时间尺度的预测精度最低,在SPI<sub>12</sub>预测精度最高,ARIMA-LSTM组合模型在各个时间尺度预测精度均高于单一模型。

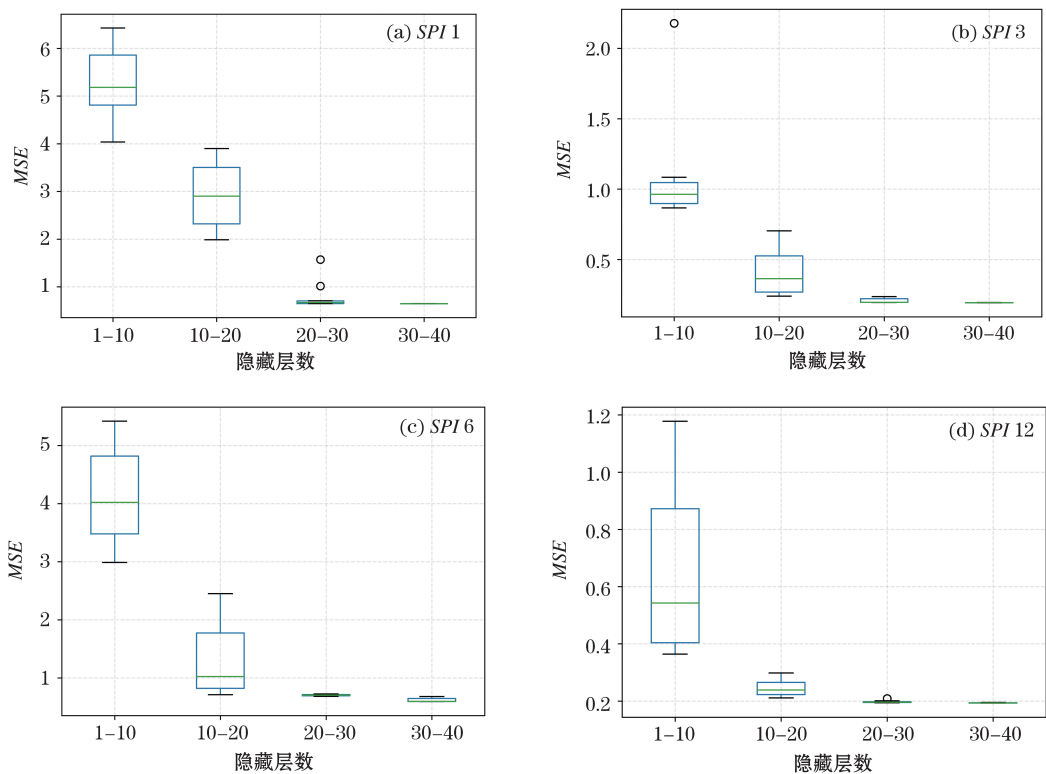


图 8 4个时间尺度的神经元隐藏层数与  $MSE$  值  
Fig. 8 Four time scale neurons hide the layers and the  $MSE$  values

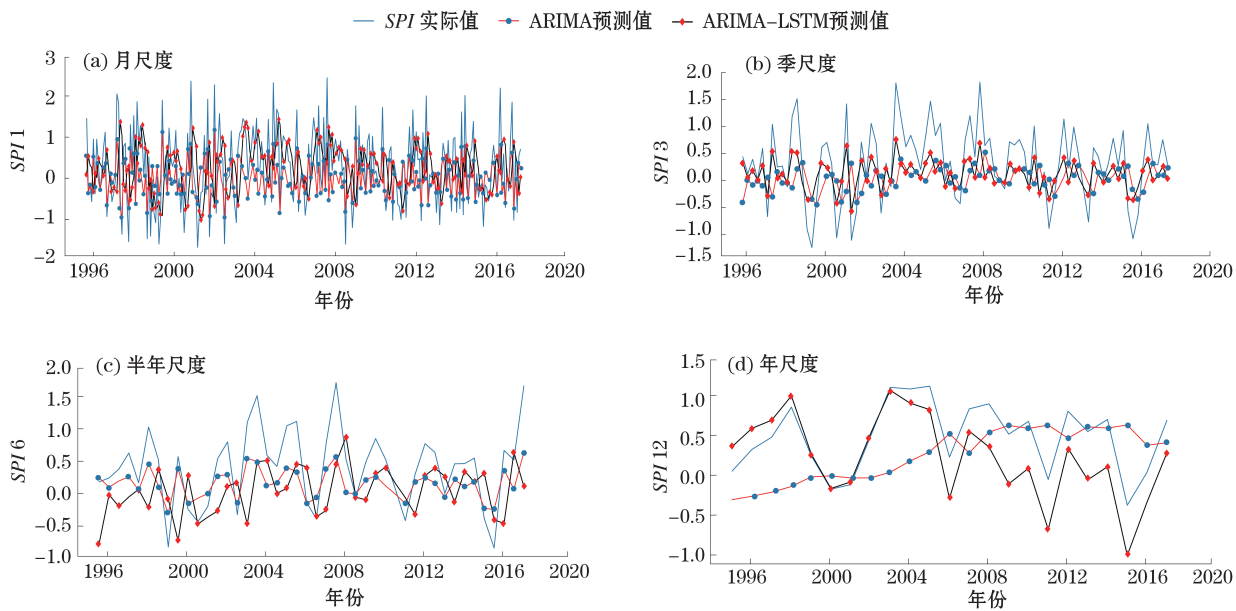


图 9 ARIMA 模型与 ARIMA-LSTM 组合模型多时间尺度  $SPI$  值的预测(1996—2017)  
Fig. 9 Forecast of multi-time scale  $SPI$  value of ARIMA model and ARIMA-LSTM combined models

4 结论

本文分别利用 ARIMA 模型和 ARIMA-LSTM 模型对多尺度  $SPI$  值进行预测,预测结果结合评价验

证指标和 ArcGIS 进行评价与空间分布展示,得到结论如下:

(1)从图 9 和表 4 可得,ARIMA 模型在 12 个月时间尺度的预测精度最高,1 个月的预测精度最

表4 2种预测模型的 $R^2$ 、 $RMSE$ 和 $MAPE$ 值  
Tab. 4  $R^2$ ,  $RMSE$  and  $MAPE$  values for two prediction models

时间尺度	预测模型	$R^2$	$RMSE$	$MAPE$
1	ARIMA	0.364 8	1.265 4	1.372 2
	ARIMA-LSTM	0.887 4	0.159 7	0.040 1
3	ARIMA	0.390 7	0.701 8	0.663 4
	ARIMA-LSTM	0.751 1	0.142 2	0.198 7
6	ARIMA	0.605 5	0.354 0	0.432 1
	ARIMA-LSTM	0.698 7	0.229 7	0.290 4
12	ARIMA	0.650 1	0.293 3	0.120 7
	ARIMA-LSTM	0.774 4	0.181 0	0.080 3

低,并且随着时间尺度的增加,预测精度逐渐增加。

(2)ARIMA-LSTM组合模型结合了线性模型和非线性模型的优点,从表4和图10中可以看出组合模型在各个时间尺度的预测精度均高于单一模型,说明组合模型适用于多尺度SPI值的预测,结合GIS强大的空间分析功能,对2017年的季尺度SPI值及其预测值进行可视化展示,发现组合模型预测值相比于单一模型在空间分布上与实际值最为接近,可为有关部门防旱抗旱提供科学依据。

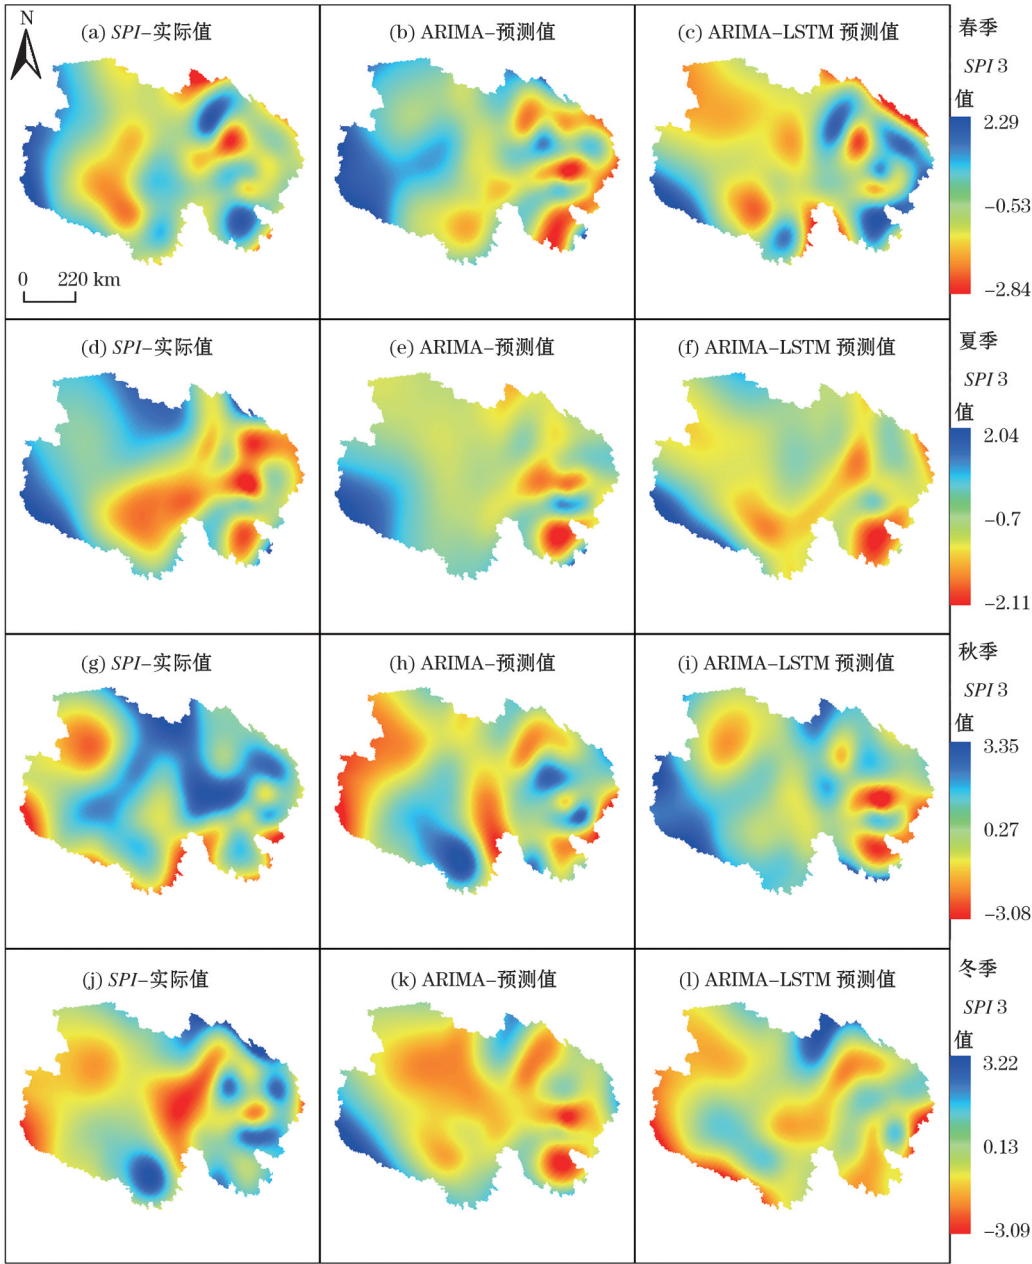


图10 ARIMA模型与ARIMA-LSTM组合模型基于季尺度的干旱空间分布

Fig. 10 Spatial distributions of seasonal drought levels in using the two forecasting models ARIMA and combined ARIMA-LSTM model



## 参考文献(References)

- [1] 高涛涛,殷淑燕,王水霞. 基于 *SPEI* 指数的秦岭南北地区干旱时空变化特征[J]. 干旱区地理, 2018, 41(4): 761–770. [GAO Taotao, YIN Shuyan, WANG Shuixia. Spatial and temporal variations of drought in northern and southern regions of Qinling Mountains based on standardized precipitation evapotranspiration index[J]. Arid Land Geography, 2018, 41(4): 761–770.]
- [2] 张乐园,王戈,陈亚宁. 基于 *SPEI* 指数的中亚地区干旱时空分布特征[J]. 干旱区研究, 2020, 37(2): 331–340. [ZHANG Leyuan, WANG Ge, CHEN Yanning. Spatial and temporal distribution characteristics of drought in Central Asia based on *SPEI* index[J]. Arid Zone Research, 2020, 37(2): 331–340.]
- [3] 李凤霞,伏洋,张国胜,等. 青海省干旱预警服务系统设计及建立[J]. 干旱地区农业研究, 2004, 22(1): 1–5. [LI Fengxia, FU Yang, ZHANG Guosheng, et al. The design and establishment of drought information service system in Qinghai Province [J]. Agricultural Research in the Arid Areas, 2004, 22(1): 1–5.]
- [4] 袁文平,周广胜. 干旱指标的理论分析与研究展望[J]. 地球科学进展, 2004, 19(6): 982–991. [YUAN Wenping, ZHOU Guangsheng. Theoretical study and research prospect on drought indices[J]. Advances in Earth Science, 2004, 19(6): 982–991.]
- [5] 沈国强,郑海峰,雷振峰. *SPEI* 指数在中国东北地区干旱研究中的适用性分析[J]. 生态学报, 2017, 37(11): 3787–3795. [SHEN Guoqiang, ZHANG Haifeng, LEI Zhenfeng. Applicability analysis of *SPEI* for drought research in northeast China [J]. Acta Ecologica Sinica, 2017, 37(11): 3787–3795.]
- [6] 张茜,张喜亮,李金建,等. 基于 *SPEI* 的四川省盆地季节性干旱时空变化特征分析[J]. 干旱地区农业研究, 2018, 36(5): 242–250. [ZHANG Han, ZHANG Xiliang, LI Jinjian, et al. *SPEI*-based analysis of temporal and spatial variation characteristics for seasonal drought in Sichuan Basin [J]. Agricultural Research in the Arid Areas, 2018, 36(5): 242–250.]
- [7] 容锦盟,周丹,罗静,等. 4种干旱指标在华北地区气象干旱监测中的适用性分析[J]. 干旱地区农业研究, 2019, 37(1): 295–276. [RONG Jinmeng, ZHOU Dan, LUO Jing, et al. Applicability analysis of four drought indices for meteorological drought monitoring in Northern China [J]. Agricultural Research in the Arid Areas, 2019, 37(1): 295–276.]
- [8] 刘庚山,郭安红,安顺清,等. 帕默尔干旱指标及其应用研究进展[J]. 自然灾害学报, 2004, 13(4): 21–27. [LIU Gengshan, GUO Anhong, AN Shunqing, et al. Research progress in Palmer drought severity index and its application[J]. Journal of Natural Disasters, 2004, 13(4): 21–27.]
- [9] VASILIADES L, LOUKAS A, LIBERIS N. A water balance derived drought index for Pinios River Basin, Greece [J]. Water Resource Manage, 2011, 25: 1087–1101.
- [10] 林盛吉,许月萍,田烨,等. 基于 *Z* 指数和 *SPI* 指数的钱塘江流域干旱时空分析[J]. 水力发电学报, 2012, 31(2): 20–26. [LIN Shengji, XU Yueping, TIAN Ye, et al. Spatial and temporal analysis of drought in Qiantang River basin based on *Z* index and *SPI* [J]. Journal of Hydroelectricity, 2012, 31(2): 20–26.]
- [11] 郭伟,李莹,杜莉丽,等. 基于 *SPI* 的山西省 1972—2012 年春夏干旱特征及对玉米产量的影响分析 [J]. 干旱地区农业研究, 2018, 36(1): 230–236. [GUO Wei, LI Ying, DU Lili, et al. Characteristic of spring and summer drought variations and its relation with maize yield in Shanxi Province in 1972—2012 based on *SPI* [J]. Agricultural Research in the Arid Areas, 2018, 36(1): 230–236.]
- [12] MCKEE T B, DOESKEN N J, KLEIST J. The relationship of drought frequency and duration to time scales [R]. Eighth Conference on Applied Climatology, American Meteorological, 1993.
- [13] 杨慧荣,张玉虎,崔恒建,等. ARIMA 和 ANN 模型的干旱预测适用性研究[J]. 干旱区地理, 2018, 41(5): 945–953. [YANG Huirong, ZHANG Yuhu, CUI Hengjian, et al. Application of ARIMA and ANN models for drought forecasting [J]. Arid Land Geography, 2018, 41(5): 945–953.]
- [14] 许德合,张棋,黄会平. ARIMA-SVR 组合模型在基于标准化降水指数干旱预测中的应用[J]. 干旱地区农业研究, 2020, 38(2): 276–282. [XU Dehe, ZHANG Qi, HUANG Huiping. Application of the combined ARIMA-SVR model in drought prediction based on the Standardized Precipitation Index [J]. Agricultural Research in the Arid Areas, 2020, 38(2): 276–282.]
- [15] 于家瑞,艾萍,袁定波,等. 基于 *SPI* 的黑龙江省干旱时空特征分析[J]. 干旱区地理, 2019, 42(5): 1059–1068. [YU Jiarui, AI Ping, YUAN Dingbo, et al. Spatial-temporal characteristics of drought in Heilongjiang Province based on standardized precipitation index [J]. Arid Land Geography, 2019, 42(5): 1059–1068.]
- [16] 韩萍,王鹏新,王彦集,等. 多尺度标准化降水指数的 ARIMA 模型干旱预测研究[J]. 干旱地区农业研究, 2008, 26(2): 212–218. [HAN Ping, WANG Pengxin, WANG Yanji, et al. Drought forecasting based on the standardized precipitation index at different temporal scales using ARIMA models [J]. Agricultural Research in the Arid Areas, 2008, 26(2): 212–218.]
- [17] 程俊. 基于 ARIMA-LSTM 混合模型的机械传动件制造企业销售预测方法研究与应用 [D]. 成都: 电子科技大学, 2018. [CHENG Jun. Research and application of sales forecasting method for mechanical transmission parts manufacturing enterprises based on ARIMA-LSTM hybrid model [D]. Chengdu: University of Electronic Science and Technology of China, 2018.]
- [18] ZHANG J F, ZHU Y, ZHANG X, et al. Developing a Long Short-Term Memory (LSTM) based model for predicting water table depth in agricultural areas [J]. Journal of Hydrology, 2018, 561: 918–929.
- [19] 苏夏羿. 基于多源遥感数据的青海省干旱监测模型研究 [D]. 杨凌: 西北农林科技大学, 2017. [SU Xiayi. Study on drought monitoring model of Qinghai province based on multi-source remote sensing data [D]. Yangling: Journal of Northwest A & F University (Natural Science Edition), 2017.]
- [20] 戴升,李林,刘彩红,等. 青海夏季干旱特征及其预测模型研究 [J]. 冰川冻土, 2012, 34(6): 1433–1440. [DAI Sheng, LI Lin, LIU Caihong, et al. Characteristics and prediction model of sum-

- mer drought in Qinghai Province[J]. Journal of Glaciology and Geocryology, 2012, 34(6): 1433 – 1440.]
- [21] 张强, 胡隐樵, 曹晓彦, 等. 论西北干旱气候的若干问题[J]. 中国沙漠, 2000, 20(4): 357 – 362. [ZHANG Qiang, HU Yinqiao, CAO Xiaoyan, et al. On some problems of arid climate system of northwest China [J]. Journal of Desert Research, 2000, 20(4): 357 – 362.]
- [22] 谢金南, 李栋梁, 尹东, 等. 甘肃省干旱气候变化及其对西部大开发的影响[J]. 气候与环境研究, 2002, 7(3): 359 – 369. [XIE Jinnan, LI Dongliang, YIN Dong, et al. Effects of Gansu arid climate change on developing of the western China [J]. Climate and Environment Research, 2002, 7(3): 359 – 369.]
- [23] 林慧, 王景才, 黄金柏, 等. 基于SPI和SPEI的淮河中上游流域气象干旱时空分布特征对比研究[J]. 水资源雨水工程学报, 2019, 30(6): 59 – 67. [LIN Hui, WANG Jingcai, HUANG Jin-bai, et al. Comparative study on spatial and temporal distribution characteristics of meteorological drought in the upper and middle reach of Huai River Basin based on SPI and SPEI [J]. Journal of Water Resources & Water Engineering, 2019, 30(6): 59 – 67.]
- [24] 中华人民共和国国家质量监督检验检疫总局. GB/T 20481—2006 中华人民共和国国家标准: 气象干旱等级[S]. 北京: 中国标准出版社, 2006. [General Administration of Quality Supervision, Inspection and Quarantine of the People's Republic of China. Classification of meteorological drought (GB/T 20481 – 2006) [S]. Beijing: Standards Press of China, 2006.]
- [25] 刘晓璐, 周延刚, 温莉, 等. 基于VSWI和SPI的2000—2016年河南省干旱特征研究[J]. 干旱区地理, 2018, 41(5): 984 – 991. [LIU Xiaolu, ZHOU Yan'gang, WEN Li, et al. Characteristics of drought in Henan Province from 2000 to 2016 based on VSWI and SPI [J]. Arid Land Geography, 2018, 41(5): 984 – 991.]
- [26] XU Dehe, ZHANG Qi, DING Yan, et al. Application of a hybrid ARIMA-SVR model based on the SPI for the forecast of drought: A case study in Henan Province, China [J]. Journal of Applied Meteorology and Climatology, 2020.
- [27] 曾妍, 王迪, 赵小娟, 等. 基于支持向量回归的关中平原冬小麦估产研究[J]. 中国农业信息, 2019, 31(6): 10 – 20. [ZENG Yan, WANG Di, ZHAO Xiaojuan, et al. Study on yield prediction of winter wheat in Guanzhong Plain based on SVR [J]. China Agricultural Informatics, 2019, 31(6): 10 – 20.]

## Application of a combined ARIMA–LSTM model based on SPI for the forecast of drought: A case study in Qinghai Province

ZHANG Jian-hai<sup>1</sup>, ZHANG Qi<sup>2</sup>, XU De-he<sup>2</sup>, DING Yan<sup>2</sup>

(1 Qinghai Hydrology and Water Resources Survey Bureau, Xining 810000, Qinghai, China;

2 North China University of Water Resources and Electric Power, Zhengzhou 450000, Henan, China)

**Abstract:** Drought prediction is a precondition to effectively mitigate the risk of drought. Daily precipitation data obtained from 38 meteorological stations in Qinghai Province, China in the period from 1958 to 2017 were used to calculate the multiscale standardized precipitation index (SPI). In addition, based on these data, the SPI sequence Autoregressive Moving Average model (ARIMA), Long Short-Term Memory model (LSTM), and ARIMA–LSTM combination model were constructed. After the calibration and verification of the model parameters, the model was used to predict multiscale SPI values using the Xining area as a case study. Moreover, the validity of all the prediction models was determined by root mean square error (RMSE) and mean absolute percentage error (MAPE). The results indicated that the RMSE values of the ARIMA–LSTM combined model in SPI1 and SPI12 were 0.159 7 and 0.181 0, respectively, which were lower than those (1.265 4 and 0.293 3) of the ARIMA model. This indicates that the prediction accuracy of the ARIMA and LSTM models for SPI was related to the timescale. Comparing the measured data (using GIS) to the data predicted by the models, the combined ARIMA–LSTM model exhibited a higher prediction accuracy compared to the single ARIMA model. In addition, the combined ARIMA–LSTM model showed an ability to fit the SPI values of different timescales.

**Key words:** drought forecast; SPI; ARIMA–LSTM; Qinghai Province